

التنبؤ بالتبخّر الإنائي الشهري في محطة حمص المناخية باستخدام الشبكات العصبية الاصطناعية

د. غطفان عبد الكريم عمّارⁱ

د. بادية يوسف حيدرⁱⁱ

علاء علي سليمانⁱⁱⁱ

(تاريخ الإيداع 6 / 6 / 2016. قُبِلَ للنشر في 20 / 9 / 2016)

□ ملخص □

يعتبر التبخّر مكوناً أساسياً في الدورة الهيدرولوجية، وهو يلعب دوراً مؤثراً في تطوير وإدارة الموارد المائية. تهدف هذه الدراسة إلى التنبؤ بالتبخّر الإنائي الشهري في محطة حمص المناخية باستخدام الشبكات العصبية الاصطناعية. وقد اعتمدت الدراسة من أجل ذلك على القيم الشهرية لدرجة حرارة الهواء والرطوبة النسبية فقط كمداخلات، واعتمدت التبخّر الإنائي الشهري كمخرج للشبكة. استُخدمت خوارزمية الانتشار العكسي في عملية تدريب وتحقيق الشبكة مع تغيير طرائق التدريب وعدد الطبقات الخفية وعدد العصبونات في كل طبقة منها، وقد أظهرت النتائج القدرة الجيدة للشبكة العصبية الاصطناعية ذات الهيكلية 1-10-2 على التنبؤ بقيم التبخّر الإنائي الشهري بمعامل ارتباط كلي (R) 96.786% وبجذر متوسط مربعات الأخطاء (RMSE) 24.52 mm/month لمجموعة البيانات الكاملة، وقد أوصت الدراسة باستخدام تقنية الشبكات العصبية الاصطناعية لتحديد العناصر الأكثر تأثيراً على التبخّر.

الكلمات المفتاحية: التبخّر الإنائي، الشبكات العصبية الاصطناعية، خوارزمية الانتشار العكسي، التنبؤ.

ⁱ أستاذ - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية .

ⁱⁱ مدرسة - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية .

ⁱⁱⁱ طالب ماجستير - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية

Prediction of Monthly Pan Evaporation in Homs Meteostation Using Artificial Neural Networks

Dr. Ghatfan Abdalkareem Ammar ⁱ

Dr. Badia Youcef Haidar ⁱⁱ

Alaa Ali Slieman ⁱⁱⁱ

(Received 6 / 6 / 2016. Accepted 20 / 9 / 2016)

□ ABSTRACT □

Evaporation is a major meteorological component of the hydrologic cycle, and it plays an influential role in the development and management of water resources. The aim of this study is to predict of the monthly pan evaporation in Homs meteostation using Artificial Neural Networks (ANNs), which based on monthly air temperature and relative humidity data only as inputs, and monthly pan evaporation as output of the network. The network was trained and verified using a back-propagation algorithm with different learning methods, number of processing elements in the hidden layer(s), and the number of hidden layers. Results shown good ability of (2-10-1) ANN to predict of monthly pan evaporation with total correlation coefficient equals 96.786 % and root mean square error equals 24.52 mm/month for the total data set. This study recommends using the artificial neural networks approach to identify the most effective parameters to predict evaporation.

Keywords: Pan Evaporation, Artificial neural networks, Back-propagation algorithm, Prediction.

ⁱ Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

ⁱⁱ Assistant Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

ⁱⁱⁱ Postgraduate student, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria,

مقدمة

تتسم الموارد المائية بأهمية متميزة قد تفوق باقي الموارد الاقتصادية الأخرى، حيث أنها تعدّ حجر الزاوية في تطوير النشاطات الزراعية والصناعية والاقتصادية المختلفة ، وتمثل المعلومات الهيدرولوجية العامل الأساس لتقويم الوضع المائي ووضع دراسات الموازنة المائية التفصيلية في أية منطقة.

يعتبر التبخر أحد أهم العوامل الهيدرولوجية، ويعرّف بأنه فقدان جزيئات الماء من السطح المائي إلى الغلاف الجوي [1]، وقد نالت دراسة هذا العامل اهتمام العديد من الباحثين بغرض إيجاد طريقة غير مباشرة لتقديره بالاعتماد على العوامل المناخية الأخرى المرتبطة به، فأجريت العديد من الدراسات لهذا الغرض، حيث قارن (Eslamian, S.S. et al. 2008) بين النوعين (FFNNs , SMVs) من نماذج الشبكات العصبية الاصطناعية في تقدير التبخر الإنثائي الشهري في خمس محطات في إيران وذلك بالاعتماد على القيم الشهرية للرطوبة النسبية والإشعاع الشمسي ودرجة الحرارة وسرعة الرياح، بالإضافة إلى الهطول المطري، وكانت نتائج كل من الأسلوبين جيدة مع أفضلية لنماذج SVMs، حيث بلغت قيمة معامل الارتباط 0.94 و 0.936 في نماذج FFNNs ونماذج SVMs على الترتيب، أما قيمة متوسط مربعات الأخطاء فقد بلغت 1265.22 و 40.98 في الأنموذجين على الترتيب أيضاً [2].

وأجرى (Boroomand. et al. 2011) دراسة لتقدير التبخر الإنثائي الشهري باستخدام الشبكات العصبية الاصطناعية في إيران، حيث دُرِّبَت الشبكة باستخدام القيم الشهرية للإشعاع الشمسي ودرجة الحرارة الصغرى والعظمى والرطوبة النسبية الصغرى والعظمى وسرعة الرياح، وكانت معاملات الارتباط خلال مرحلتي التدريب والاختبار 97.4% و 97.3% على الترتيب، وكان الخطأ النسبي الأعظمي في المرحلتين على الترتيب 18% و 24%، وقد تم الاستنتاج على أنّ أسلوب الشبكات العصبية الاصطناعية هو أسلوب ملائم لتمثيل الظاهرة وقادر على تقدير قيمها بشكل دقيق [3].

أما (Kumar, P. et al. 2012) فقد أجرى بدراسة مشابهة لتقدير التبخر الإنثائي الشهري في الهند باستخدام الشبكات العصبية الاصطناعية اعتماداً على قيم الرطوبة النسبية والإشعاع الشمسي ودرجة الحرارة وسرعة الرياح، واستنتج القدرة الجيدة لهذه النماذج في عملية التقدير، حيث بلغ معامل الارتباط 0.9311 خلال مرحلة التدريب و 0.9326 خلال مرحلة الاختبار، أما قيمة جذر متوسط مربعات الأخطاء فقد بلغت 1.07 mm/day خلال مرحلة التدريب و 0.9863 mm/day خلال مرحلة الاختبار [4].

في حين قام (Singh, S.K. et al. 2013) بدراسة لتقدير التبخر نتح اليومي في مجموعة من المحطات المناخية في الهند باستخدام الشبكات العصبية الاصطناعية، بالاعتماد على قيم درجات الحرارة الصغرى والعظمى، والرطوبة النسبية الصغرى والعظمى، الإشعاع الشمسي وسرعة الرياح كمدخلات للشبكات العصبية، أما المخرجات فكانت قيم التبخر نتح اليومي المقاسة باستخدام الليزيمتر، وقد أظهرت النتائج إمكانية استخدام نماذج الشبكات العصبية الاصطناعية بمعامل ارتباط 0.9824 خلال مرحلة التدريب و 0.9448 خلال مرحلة الاختبار [5].

وقارن (Al-Aboodi, Ali. 2014) بين نظام الاستدلال العصبي الضبابي التكيفي ANFIS والانحدار الخطي في تقدير التبخر الإنثائي الشهري، ووجد أن نظام ANFIS يحسّن من الدقة بحدود 5%، حيث بلغت قيمة جذر متوسط مربعات الأخطاء RMSE في نموذجي ANFIS والانحدار الخطي 63.596 mm/month و 64.42 mm/month

على الترتيب، أما معامل الارتباط R فقد بلغ 0.987 و 0.938 في نموذجي ANFIS والانحدار الخطي على الترتيب [6].

في حين قارن (Dalkilic, Y. et al. 2014) بين نماذج الشبكات العصبية الاصطناعية ومعادلة بنمان التجريبية في تقدير التبخّر الإنائي اليومي، وأظهرت النتائج أفضلية نماذج الشبكات العصبية من النوع LMANN التي تعتمد على خوارزمية Levenberg–Marquardt في عملية التدريب حيث بلغت قيمة متوسط مربعات الأخطاء لهذا النوع من الشبكات خلال مرحلة الاختبار $2.27 \text{ mm}^2/\text{day}$ [7].

أما (Pakhale, G.k. et al. 2015) فقد قام بدراسة لتقدير التبخّر نتح المرجعي اليومي في حوض Ameleke في أثيوبيا باستخدام الشبكات العصبية الاصطناعية مستخدماً فيها الأداة MARS في تحديد الهيكلية وعدد العصبونات الأكثر ملاءمة للشبكة العصبية، وقارن النتائج مع طريقة بنمان مونثيث، فتبين أن الشبكات العصبية هي الطريقة الأفضل، ويمكن اعتمادها من أجل السيناريوهات المستقبلية [8].

أهمية البحث وأهدافه

تعود أهمية البحث إلى ضرورة إيجاد طريقة قادرة على التقدير والتنبؤ الدقيق بالتبخّر الإنائي الشهري في محطة مدينة حمص المناخية، وبالتالي إمكانية إجراء دراسات الموازنة المائية التفصيلية ووضع الخطط المستقبلية في سبيل تنمية وإدارة الموارد المائية المتاحة في المنطقة والإفادة منها بالشكل الأمثل.

يهدف البحث إلى وضع نموذج شبكة عصبية اصطناعية للتنبؤ بالتبخّر الإنائي الشهري في محطة حمص المناخية بالاعتماد على القيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية فقط.

موقع منطقة البحث:

جُمعت البيانات من محطة مدينة حمص المناخية التي تقع في المنطقة الوسطى من الجمهورية العربية السورية، على ارتفاع 483 m عن مستوى سطح البحر، وعلى خط عرض (34° 45') شمالاً وخط طول (36° 43') شرقاً، ويبين الشكل (1) موقع المحطة المدروسة.


طرائق البحث ومواده :

تعرف الشبكات العصبية الاصطناعية بأنها عبارة عن أنظمة ترابطية تعتمد في صياغتها على محاكاة بنية وآلية عمل الخلايا البيولوجية في الكائنات الحية، وذلك من ناحية القدرة على التعلم من أنماط مختلفة من البيانات والسرعة العالية في إجراء عمليات المعالجة، حيث تتكوّن هذه الشبكات من وحدات للمعالجة العصبية Processing Element تدعى بالعصبونات، يعمل كل منها كذاكرة محلية Local Memory تستخدم في إجراء عمليات المعالجة المختلفة.



الشكل (1) : موقع محطة مدينة حمص المناخية.

تتم عملية المعالجة ضمن العصبون الاصطناعي من خلال ضرب كل قيمة من المدخلات بوزن محدد، ثم تُجمع المدخلات الموزونة ويُضاف إليها عامل انحياز، وبعد ذلك تُطبَّق دوال تفعيل (تنشيط) Activation Function، والتي تُحدَّد بحسب نوعها قيمة المخرجات الناتجة عن العصبون، ويوضح الشكل (2) مراحل عمل العصبون الاصطناعي.



الشكل (2): مراحل عمل العصبون الاصطناعي.


مكونات الشبكات العصبية الاصطناعية

تتكوّن الشبكة العصبية الاصطناعية بشكل أساسي من طبقة الدخل Input layer التي تحتوي على عدد من العصبونات ممثل لعدد مدخلات الشبكة العصبية، وطبقة مخفية Hidden layer واحدة أو أكثر والتي تضيف المرونة على عملية بناء الدوال الناقلة بين المدخلات والمخرجات [9]، ثم طبقة الخرج للشبكة Output layer.

الشبكات العصبية الاصطناعية ذات التغذية الأمامية

تعدّ من أكثر أنواع الشبكات العصبية الاصطناعية استخداماً، حيث يتكوّن هذا النوع من الشبكات من طبقتين على الأقل، كما وتوجد في غالب الأحيان طبقة خفية أو أكثر بين طبقتي الدخل والخرج، وسميت بهذا الاسم لأنّ جهة

انتقال البيانات وإجراء العمليات الحسابية تكون إلى الأمام من طبقة الدخل إلى طبقة الخرج عبر الطبقات الخفية للشبكة، الشكل (3).



الشكل (3): نموذج لشبكة عصبية اصطناعية ذات تغذية أمامية.

خوارزميات التدريب للشبكات العصبية الاصطناعية

وتعدّ عملية التعليم والتدريب للشبكات العصبية هي الأساس في تجهيز هذه الشبكات لأداء عمليات التعرف المختلفة، ويتم ذلك من خلال مجموعة من خوارزميات التدريب، وبشكل عام يمكن أن تتم عملية التدريب للشبكة بإحدى الطريقتين الآتيتين:

■ التدريب الموجّه Supervised Learning

وتعتمد هذه الطريقة في التدريب على عرض مجموعة بيانات التدريب على الشبكة العصبية على شكل أزواج لمدخلات ومخرجات الشبكة، وتستخدم الشبكة الفرق بين مخرجات الشبكة والمخرجات الحقيقية في حساب الخطأ وتعديل الأوزان للوصول إلى أفضل النتائج، وتعتبر خوارزمية الانتشار العكسي للخطأ Error Back-Propagation Algorithm من أفضل خوارزميات التدريب الموجّه للشبكات العصبية الاصطناعية ذات التغذية الأمامية.

■ التدريب غير الموجّه Unsupervised Learning

ويعتمد التدريب في هذا النوع على قدرة الشبكات العصبية على اكتشاف الملامح المميزة لمجموعة البيانات، وعلى قدرتها على التعميم، بدون عرض أية أمثلة لما يجب أن تنتج الشبكة، وذلك على عكس التدريب بالطريقة الأولى [10].

تقييم البيانات

يتم بعد تجميع البيانات تحويل جميع القيم إلى قيم بين الـ 0 والـ 1 وذلك قبل إدخالها إلى الشبكة من خلال عملية التقييم التي يمكن إجراؤها بعدة طرق، وفي هذه الدراسة تم اعتماد المعادلة الآتية في عملية التقييم [11]:

$$P_{norm} = 0.5 \left[\frac{P - P_{mean}}{P_{max} - P_{min}} \right] + 0.5 \quad (1)$$

وذلك حيث أنّ: P : القيمة الأصلية. P_{norm} : القيمة بعد التقييم. P_{mean} : متوسط القيم. P_{max} : أعلى قيمة. P_{min} : أدنى قيمة.

تستخدم هذه القيم خلال مراحل بناء الشبكة العصبية الاصطناعية، ثم تُعاد القيم التي تنتج بعد إجراء عملية المحاكاة Simulation إلى حالتها الأصلية قبل التقييم.

طريقة معادلة ايفانوف

وتستخدم معادلة ايفانوف في حساب التبخر من السطوح المائية الحرّة بالاعتماد على القيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية وفق ما يلي [12]:

$$E = 0.0018.(T + 25)^2(100 - RH) \quad (2)$$

حيث أن: T : القيمة الوسطية الشهرية لدرجة حرارة الهواء.

RH : الرطوبة النسبية %.

E : التبخر في الشهر mm.

معايير التقييم

يوجد العديد من المعايير للمقارنة بين الشبكات العصبية وتحديد الشبكة ذات الدقة الأفضل، وفي هذه الدراسة تم اعتماد قيم جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R، والتي تعطى بالعلاقات كما يلي [6]:

$$RMSE = \left[\frac{\sum_{i=1}^n (p_i - o_i)^2}{N} \right]^{0.5} \quad (3)$$

$$R = \frac{\sum_{i=1}^n (p_i - \bar{p})(o_i - \bar{o})}{\left[\sum_{i=1}^n (p_i - \bar{p})^2 \cdot \sum_{i=1}^n (o_i - \bar{o})^2 \right]^{\frac{1}{2}}} \quad (4)$$

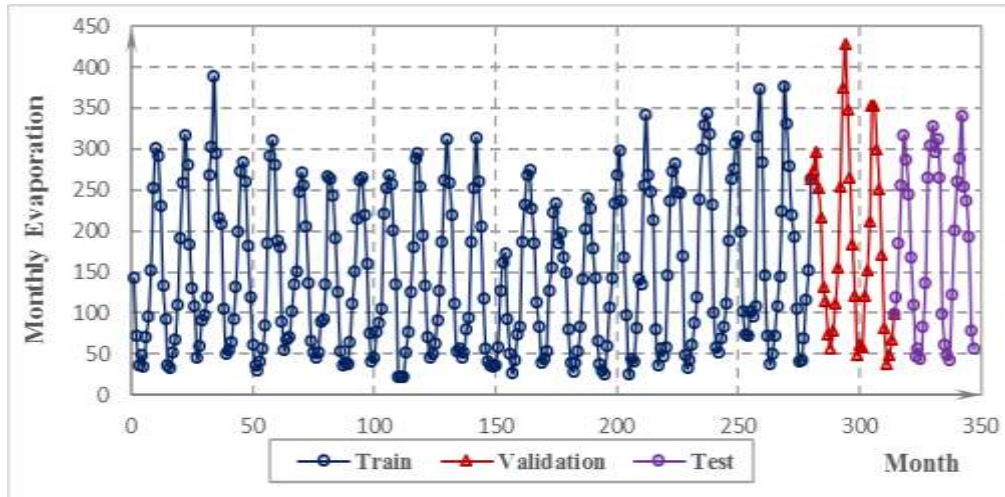
حيث أن: p_i : القيمة المتنبأ بها. \bar{p} : المتوسط الحسابي للقيم المتنبأ بها. N : عدد البيانات.
 o_i : القيمة المقاسة. \bar{o} : المتوسط الحسابي للقيم المقاسة.

النتائج والمناقشة:

جُمعت البيانات المتوفرة في محطة حمص المناخية موضوع البحث في الفترة الممتدة بين عامي (1975-2004) ثم قُيست باستخدام المعادلة (1)، وأدخلت إلى الشبكة العصبية الاصطناعية المكونة من عصبونين في طبقة الدخل للشبكة ممثلين للقيم الوسطية الشهرية لدرجة حرارة الهواء والرطوبة النسبية، يقابلها عصبون واحد في طبقة الخرج ممثل لقيمة التبخر الإنائي الشهري، وتضمنت هذه البيانات 347 قيمة شهرية تم تقسيمها إلى ثلاث مجموعات للتدريب والتحقق والاختبار وفق عدة نسب من خلال مجموعة من التجارب، وتبين أن التقسيم الأفضل والذي يعطي النتائج الأكثر دقة هو 80% لمجموعة التدريب و 10% لمجموعة التحقق و 10% لمجموعة الاختبار، وذلك لتقارب المؤشرات الإحصائية (المتوسط الحسابي والانحراف المعياري) بين المجموعات الثلاث بالاعتماد على نسب التقسيم هذه، وبالتالي تضمنت مجموعة التدريب على 279 قيمة شهرية ابتداءً من شهر تشرين الأول عام 1975، في حين احتوت كل من مجموعتي التحقق والاختبار على 34 قيمة، ويحتوي الجدول (1) على بعض المؤشرات الإحصائية للعوامل المناخية المستخدمة خلال كل مجموعة من هذه المجموعات، ويبين الشكل (4) قيم التبخر الإنائي الشهري في كل مجموعة من المجموعات.

الجدول (1): بعض المؤشرات الإحصائية للعوامل المناخية المستخدمة.

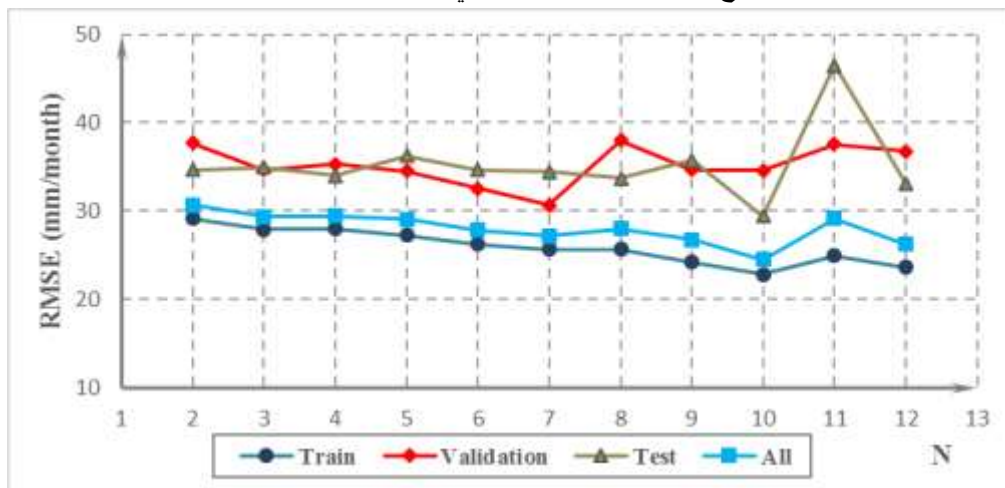
	مجموعة التدريب	مجموعة التحقق	مجموعة الاختبار	جميع البيانات
النسبة	80%	10%	10%	100%
عدد البيانات	279	34	34	347
درجة حرارة الهواء °C				
المتوسط الحسابي	16.4	18.1	18.1	16.7
الانحراف المعياري	7.1	7.7	7.5	7.2
أكبر قيمة	29.2	29.5	27.9	29.5
أصغر قيمة	3.4	6.0	6.5	3.4
الرطوبة النسبية %				
المتوسط الحسابي	66.0	65.4	66.7	66.0
الانحراف المعياري	10.0	9.9	9.8	10.0
أكبر قيمة	87.0	87.4	84.4	87.4
أصغر قيمة	44.0	48.7	51.1	44.0
التبخر mm/month				
المتوسط الحسابي	147.2	186.1	182.7	154.5
الانحراف المعياري	93.8	112.4	101.4	97.3
أكبر قيمة	388.9	427.9	341.2	427.9
أصغر قيمة	22.0	38.2	43.3	22.0



الشكل (4): بيانات التبخر الإنثائي الشهري المستخدمة في الدراسة.


استُخدم برنامج الماتلاب وحزم الأدوات الملحقة به في عملية بناء الشبكات العصبية وتدريبها، حيث أُجري عدد كبير جداً من التجارب على شبكات عصبية ذات بُنى مختلفة من خلال التغيير في عدد العصبونات في الطبقة الخفية وتوابع التفعيل المستخدمة في كل من الطبقة الخفية وطبقة الخرج للشبكة، وكذلك من خلال التغيير في الخوارزميات

المستخدمة في تدريب الشبكة، حيث دُرِّبَت كلُّ شبكة من هذه الشبكات 1000 مرّة ثم حسبت قيمة جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R لكل مجموعة من المجموعات. بيّنت النتائج أن توابع التفعيل ذات الدالة القطعية Sigmoid Function هي الأفضل وتتناسب طريقة التقييم المستخدمة، وأن خوارزمية التدريب (LM) Levenberg–Marquardt تساعد في الوصول إلى أقل قيمة لجذر متوسط مربعات الأخطاء RMSE. ويبين الشكل (5) التغيرات في قيمة جذر متوسط مربعات الأخطاء RMSE خلال المراحل الثلاث لبناء الشبكة، بالإضافة إلى القيمة الكلية مع تغيير عدد العصبونات في الطبقة الخفية.



الشكل (5): تغيّر قيمة جذر متوسط مربعات الأخطاء RMSE مع تغيّر عدد العصبونات في الطبقة الخفية خلال مراحل بناء الشبكة.

نلاحظ أن الشبكة العصبية الاصطناعية التي تحتوي على عشر عصبونات في الطبقة الخفية ANN(2,10,1) التي تعتمد على تابع التفعيل Tan Sigmoid هي الأفضل، حيث كانت قيم جذر متوسط مربعات الأخطاء RMSE تساوي 22.8 mm/month خلال مرحلة التدريب، و 31.62 mm/month خلال مرحلة التحقق، و 29.44 mm/month خلال مرحلة الاختبار، في حين بلغت القيمة الكلية خلال المراحل الثلاث 24.52 mm/month. ويظهر الشكل (6) أداء هذه الشبكة والتناقض في قيمة متوسط مربع الخطأ خلال مرحلة تدريب الشبكة Train، واختيار الدورة التكرارية 179 التي تقابل أقل قيمة لمتوسط مربع الخطأ المعياري خلال مرحلة التحقق Validation.





الشكل (6): أداء الشبكة (2,10,1) خلال مراحل التدريب والتحقق والاختبار.

وبالإضافة إلى ذلك فقد أعطت الشبكة العصبية الاصطناعية ذات الهيكلية (2,10,1) قيمة عالية لمعامل

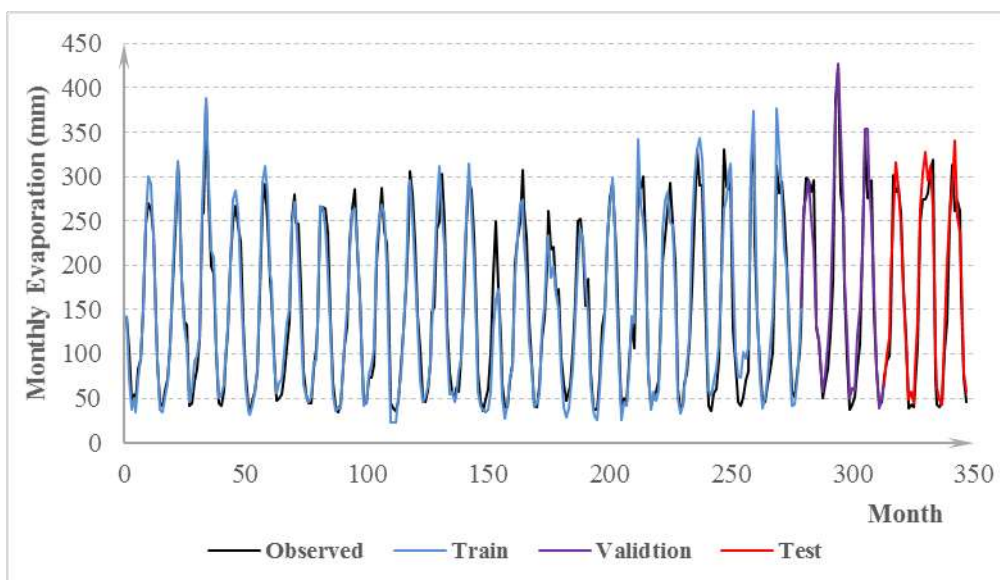
الارتباط بين القيم المقاسة والقيم الناتجة عن الشبكة، حيث كانت خلال مراحل التدريب والتحقق والاختبار على الترتيب: 0.97، 0.964، 0.964، أما قيمة الارتباط الكلية فقد بلغت 0.968 وذلك كما هو موضح في الشكل (7)، في حين يظهر الشكل (8) مقارنة بين القيم الحقيقية والقيم المنتبأ بها الناتجة عن الشبكة خلال المراحل المختلفة من عملية بناء الشبكة.

ومن جهة أخرى حُسبت بغرض المقارنة قيم التبخر الإنثائي الشهري باستخدام معادلة ايفانوف التي تعتمد على القيم ذاتها المستخدمة كمدخلات للشبكة العصبية الاصطناعية، أي القيم الشهرية لدرجة الحرارة والرطوبة النسبية، فأظهرت النتائج ضعفاً في تمثيل قيم الظاهرة، حيث بلغت قيمة جذر متوسط مربعات الأخطاء RMSE على كامل مجموعة البيانات 56.1 mm/month، ومعامل الارتباط الكلي 0.95948، ومُثلت نتائج المقارنة مع نتائج الشبكة العصبية الاصطناعية في الشكل (9)، وذلك على قيم فترتي التحقق والاختبار للشبكة العصبية الاصطناعية، أي على قيم لم تستخدم في عملية تدريب الشبكة.






الشكل (7): الارتباط بين القيم المقيسة والمتنبأ بها.



الشكل (8): مقارنة بين قيم التبخر الإنائي الحقيقية والقيم الناتج عن الشبكة خلال مراحل التدريب والتحقق والاختبار .



الشكل (9): مقارنة بين القيم الحقيقية للتبخر الإنائي الشهري والقيم الناتجة عن الشبكة العصبية الاصطناعية والقيم الناتجة عن معادلة إيفانوف خلال مرحلتي التحقق والاختبار فقط.

الاستنتاجات والتوصيات:

- أثبتت الشبكة العصبية الاصطناعية ذات الهيكلية 1-10-2، ومعامل الارتباط الكلي 0.96786 ويجذر متوسط مربعات الأخطاء 24.52 mm/month لمجموعة البيانات الكلية، قدرتها على التنبؤ بالتبخر الإنائي الشهري في محطة حمص المناخية.
- بينت المقارنة بين طريقتي الشبكات العصبية الاصطناعية ومعادلة إيفانوف أن الشبكات العصبية هي الأفضل في عملية التقدير والتنبؤ بقيم التبخر الإنائي الشهري، حيث بلغ جذر متوسط مربعات الأخطاء لمجموعة البيانات الكاملة 24.52 mm/month و 56.1 mm/month في طريقتي الشبكة العصبية الاصطناعية ومعادلة إيفانوف على الترتيب، في حين بلغ معامل الارتباط الكلي 96.786 % و 95.948 % في الشبكة العصبية الاصطناعية ومعادلة إيفانوف على الترتيب.
- أظهرت النتائج الموثوقة العالية للشبكات العصبية الاصطناعية في عملية التقدير والتنبؤ بالتبخر الإنائي الشهري بالاعتماد على قيم درجة الحرارة والرطوبة النسبية فقط.
- يوصى بإجراء دراسة تحليل حساسية قيم التبخر الإنائي للعوامل المناخية باستخدام الشبكات العصبية الاصطناعية، وتحديد أكثر العناصر تأثيراً على قيمة التبخر للحصول على أكبر دقة ممكنة في عملية التنبؤ.

المراجع:

1. بكر، ذر انتصار. استخدام نموذج (ARIMA) في استكمال السلسلة الزمنية لقيم التبخر في مدينة بغداد. مجلة جامعة ديالى، العدد 10، 2014.
2. ESLAMIAN, S. S; GOHARI, S. A; BIABANKI, M; MALEKIAN, R; *Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines*. Journal of Applied Sciences 8 ,19, 2008, 3497-3502.
3. BORROOMAND-NASAB, B; JOORABIAN, M. *Estimating Monthly Evaporation Using Artificial Neural Networks*. Journal of Environmental Science and Engineering, 5, 2011, 88-91.
4. KUMAR, P; TIWARI, A. K. *Evaporation Estimation Using Artificial Neural Network*. International Journal of Computer Theory and Engineering, Vol. 4, No. 1, 2012.
5. SINGH, S.K; LAI, C; SHARMA, D.K; MATHUR, S; SHAGI, N.C; CHAND, K. *Comparison of measured and predicted Evapotranspiration using Artificial Neural Network model*. Journal of Academia and Industrial Research. Vol. 1, No 12, 2013, 816-819.
6. AL-ABOODI, A.H. *Evaporation Estimation Using Adaptive Neuro-Fuzzy Inference System and Linear Regression*. Eng. &Tech. Journal, Vol. 32, Part (A), No.10, 2014.
7. DALKILIC, Y; OKKAN, U; BAYKAN, N. *Comparison of Different Ann Approaches in Daily Pan Evaporation Prediction*. Journal of Water Resource and Protection, 6, 2014, 319-326.
8. PAKHALE, G. K; NALE, J. P; TEMESGEN, W. B; MULUNEH, W. D. *Modelling Reference Evapotranspiration Using Artificial Neural Network: A Case Study of Ameleke watershed, Ethiopia*. International Journal of Scientific and Research Publications, Volume 5, Issue 4, 2015.
9. راشد، صفوان ناظم؛ رشيد، خيري بدل؛ زكي، عزة حازم. مقارنة بين اسلوبي الشبكات العصبية الاصطناعية والمربعات الصغرى للنماذج الخطية وغير الخطية مع التطبيق . المجلة العراقية للعلوم الإحصائية (21)، 2012، 246-265.
10. BASHEER, I, A ; HAJMEER, M . Artificial neural networks: fundamentals, computing, design, and application. Journal of Microbiological Methods 43, 2000, 3-31.
11. KUMAR, M; RAGHUWANSHI, N. S; SINGH, R; WALLENDER, W. W; PRUITT, W. O. *Estimating Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering, 2002.
12. FILIMONOVA, M; TRUBETSKOVA, M. *Calculation of evaporation from the Caspian Sea surface*. International Symposium on Stochastic Hydraulics, 2005.